

**基于梯度信息约束的双视角CT重建算法**

胡海, 孙雪琴, 李毅红, 陈平

**Dual-view CT Reconstruction Algorithm Based on Gradient Information Constraints**

HU Hai, SUN Xueqin, LI Yihong, and CHEN Ping

在线阅读 View online: <https://doi.org/10.15953/j.ctta.2025.116>**您可能感兴趣的其他文章****Articles you may be interested in****基于双域自适应网络的岩矿样工业CT图像金属伪影校正算法研究**

Metal Artifact Reduction Algorithm for CT Images of Rock and Mineral Samples Based on Dual-domain Adaptive Network

CT理论与应用研究. 2022, 31(6): 783–792

**基于光流法的稀疏光场稠密重建算法**

Dense Reconstruction Algorithm of Sparse Light-field Based on Optical Flow Method

CT理论与应用研究. 2022, 31(2): 173–185

**基于非局部广义总变分正则化的稀疏角度CT重建算法**

Sparse View CT Reconstruction Algorithm Based on Non-Local Generalized Total Variation Regularization

CT理论与应用研究. 2025, 34(1): 129–139

**基于对抗式残差密集深度神经网络的CT稀疏重建**

Sparse CT Reconstruction Based on Adversarial Residual Dense Deep Neural Network

CT理论与应用研究. 2022, 31(2): 163–172

**基于梯度特征聚类分析的大尺寸物体CT图像环状伪影校正方法**

Ring-artifact Correction Method for Large-size Object CT Images Based on Gradient Featured Cluster Analysis

CT理论与应用研究. 2024, 33(6): 781–789

**基于相对TV最小的CT图像重建算法**

Computed Tomography Reconstruction Algorithm Based on Relative Total Variation Minimization

CT理论与应用研究. 2023, 32(2): 153–169



关注微信公众号, 获得更多资讯信息

胡海, 孙雪琴, 李毅红, 等. 基于梯度信息约束的双视角 CT 重建算法[J]. CT 理论与应用研究(中英文), 2025, 34(4): 525-533. DOI:[10.15953/j.ctta.2025.116](https://doi.org/10.15953/j.ctta.2025.116).

HU H, SUN X Q, LI Y H, et al. Dual-view CT Reconstruction Algorithm Based on Gradient Information Constraints[J]. CT Theory and Applications, 2025, 34(4): 525-533. DOI:[10.15953/j.ctta.2025.116](https://doi.org/10.15953/j.ctta.2025.116). (in Chinese).

## 基于梯度信息约束的双视角 CT 重建算法

胡海<sup>1a,2</sup>, 孙雪琴<sup>1a,2</sup>, 李毅红<sup>1b</sup>, 陈平<sup>1a,2✉</sup>

1. 中北大学 a) 信息与通信工程学院; b) 数学学院, 太原 030051
2. 极限环境光电动态测试技术与仪器全国重点实验室, 太原 030051

**摘要:** 计算机断层成像(CT)技术凭借其无损检测、分辨率高和可视化等特点, 在工业检测领域展现出显著应用价值。然而, 在某些工业检测场景中, 极端受限的扫描条件导致投影数据获取难度大, 传统重建方法应用受限。为应对这一挑战, 本研究提出一种适用于快速CT成像的正交双视角三维重建网络。提出的方法基于编解码架构, 并使用二维卷积代替三维卷积, 用特征通道维度推断CT体积的深度, 提高模型的推理速度。同时引入梯度信息、梯度损失来增强网络对边缘的恢复能力。该方法在核桃和引信数据集上进行验证, 实验结果表明, 重建分辨率为128的体积仅需0.19s, 且重建图像的结构相似性高于0.98。该方法从双视角2D投影中推断出3D CT体积的有效能力, 展现其在快速CT成像中的未来潜力。

**关键词:** 双视角投影; CT重建; 编解码网络; 梯度约束

DOI:[10.15953/j.ctta.2025.116](https://doi.org/10.15953/j.ctta.2025.116) 中图分类号: TP 391.41; O 242 文献标识码: A

## Dual-view CT Reconstruction Algorithm Based on Gradient Information Constraints

HU Hai<sup>1a,2</sup>, SUN Xueqin<sup>1a,2</sup>, LI Yihong<sup>1b</sup>, CHEN Ping<sup>1a,2✉</sup>

1. a).College of Information and Communication Engineering; b).College of Mathematics, North University of China, Taiyuan 030051, China
2. The State Key Laboratory of Extreme Environment Optoelectronic Dynamic Testing Technology and Instrument, Taiyuan 030051, China

**Abstract:** Computed tomography (CT) technology has demonstrated significant application value in industrial inspection owing to its non-destructive testing capabilities, high resolution, and visualization features. However, in certain industrial inspection scenarios, extremely limited scanning conditions pose substantial challenges for projection data acquisition, restricting the application of traditional reconstruction methods. To address this challenge, this study proposes an orthogonal dual-view 3D reconstruction network tailored for rapid CT imaging. The proposed method employs an encoder-decoder architecture, utilizing 2D convolutions instead of 3D convolutions to infer the depth dimension of CT volumes through feature channels, thereby enhancing model inference speed. Additionally, gradient information and gradient loss are introduced to strengthen the edge recovery capability of the network. The method is validated on walnut and Fuze datasets. Experimental results showed that reconstructing a volume with a resolution of 128 required only 0.19 s, and the structural similarity of the reconstructed images was higher than 0.98. This approach demonstrates effective capability in inferring 3D CT volumes from dual-view 2D projections, revealing its future potential in rapid CT imaging.

**Keywords:** dual-view projection; CT reconstruction; encoder-decoder network; gradient constraint

---

收稿日期: 2025-03-30。

**基金项目:** 国家重点研发计划(半导体器件封装质量智能检测关键技术研究与应用示范(2023YFE0205800)); 国家自然科学基金(面向固体火箭发动机内结构剖面动态测试的双视角X射线快速CT成像(62471442)); 国家自然科学基金(面向黄土质煤岩层孔隙结构动态表征的宽视场高分辨动态CT成像研究(U23A20285)); 山西省自然科学基金(基于双视角X射线CT成像的固体火箭发动机内结构剖面测试方法(202303021211149)); 山西省重点研发计划复杂产品三维CT实时成像及缺陷智能识别(202302150401011))。

**第一作者:** 胡海, 男, 硕士研究生, 主要从事基于深度学习的CT重建技术研究, E-mail: [hh15955716594@163.com](mailto:hh15955716594@163.com)。

**通信作者:** 陈平<sup>✉</sup>, 男, 教授、博士生导师, 主要从事图像处理与重建、光电检测、人工智能等方面的研究, E-mail: [pc0912@163.com](mailto:pc0912@163.com)。

计算机断层成像 (computed tomography, CT) 技术凭借其非破坏性、高效、非接触等特点, 在工业中具有广阔的应用空间<sup>[1-2]</sup>。目前 CT 成像技术主要分为传统重建和深度学习重建两大类别。

传统重建方法大致可以分为两类: 解析重建算法和迭代重建算法。通过数百个 X 射线投影, 传统重建算法可以近似地重建 CT 体积。之后有学者把压缩感知引入到 CT 重建中开发了基于正则化的重建方法<sup>[3]</sup>, 把先验信息整合到重建模型中, 成功减少了所需投影图像的数量。然而在一些条件受限的应用场景中, 只能获取非常有限的投影图像, 如工业产品在线检测、瞬态毁伤动态测试等, 依靠传统方法和正则化方法无法获得高质量的结果。因此, 从超稀疏采样的投影中重建图像以加快 CT 成像过程成为研究的热点问题。超稀疏视角 CT 成像可突破传统采样定理限制, 实现重建效率的阶跃式提升。

近来, 随着深度学习的快速发展, 数据驱动的单/双视角 CT 重建算法应运而生<sup>[4]</sup>。在卷积神经网络 (convolutional neural networks, CNN) 领域, Li 等<sup>[5]</sup>通过编解码网络并结合跳跃连接, 实现了从单视角 X 射线投影重建 3D CT 体积; Tan 等<sup>[6]</sup>在特征提取的过程中加入注意力机制和多尺度特征提取模块将 2D 特征转换为 3D 特征, 并与相应的 3D 生成模块进行特征融合, 实现利用单个 2D 影像生成 3D 体积数据; Liu 等<sup>[7]</sup>设计了混合网络 HybRecon, 用于微小缺陷恢复, 将 CT 重建任务分解为 3 个子任务, 对应于 3 个不同的模块, 并且 3 个模块的训练有先后顺序; Sun 等<sup>[8]</sup>的 X-ray2CTNet, 借助密集连接与跳跃连接, 成功实现了基于双视角投影的固体火箭发动机药柱燃面的三维重建。尽管 CNN 在图像重建方面取得了显著进展, 但随着研究的深入和应用需求的不断提升, 新的技术方向也应运而生。

生成对抗网络 (generative adversarial network, GAN) 以其独特的对抗训练机制, 为图像重建领域带来了新的思路。Ying 等<sup>[9]</sup>提出的 X2CT-GAN 模型通过 2D 到 3D 跨维映射、特征编解码、特征融合和对抗性训练, 实现双视角医学图像重建; Huang 等<sup>[10]</sup>提出了 3DSP-GAN 模型, 通过构建 3D-3D 的生成器网络来减少跨维图像的语义差距, 并提出由 3D 软池化操作组成的下采样模块, 成功实现了肺部 CT 高质量重建。然而, 基于 GAN 的方法在应用过程中暴露出两大主要问题, 一方面, 训练过程稳定性欠佳; 另一方面, 生成的内容可能出

现虚假结构。这些问题促使研究人员不断探索新的技术。

随着 Transformer 架构的突破, 其强大的特征提取和建模能力也逐渐引起了图像重建领域学者的关注。Shi 等<sup>[11]</sup>提出了名为 XRayWizard 的新型模型, 它使用 Vision Transformer 块来编码 2D X 射线图像, 并在每个 Transformer Block 的末尾引入一个池化层来提取特征信息, 成功实现单个 2D 胸部 X 射线图像重建 3D 肺体积; Wang 等<sup>[12]</sup>提出了采用 Transformer 网络模块来增强 X 射线图像特征表示的 TRCTGAN, 用于从双平面 X 射线图像重建胸部 CT 体积。然而, Transformer 架构高模型复杂度的固有局限限制了其在实际场景中的广泛应用。

尽管基于深度学习的单/双视角 CT 重建算法已取得显著进展, 但当前该类三维 CT 重建算法普遍将三维卷积作为核心运算单元, 通过三维卷积的空间维度感知特性实现从投影数据到体素空间的特征映射。然而, 级联形式的三维卷积会致使参数量急剧增加, 显存消耗显著, 严重制约了重建体素维度与重建速率<sup>[13]</sup>。在 2D X 射线投影到 3D CT 重建的任务中, 使用两个从正交方向捕获的投影, 可以实现信息互补, 帮助模型获得更准确的结果。

在此背景下, 本文提出适用于快速 CT 成像的双视角三维重构网络。该网络基于编解码架构, 利用特征通道维度推断 CT 体积的深度, 从而避免解码阶段使用级联的三维卷积带来的显存急剧消耗。同时为提高对先验信息的利用和加快模型的收敛速度, 该模型还引入了梯度损失函数。本文的工作点总结如下。

(1) 设计一个基于正交双视角投影的快速三维重建网络, 仅需要正交双视角投影, 便可以快速准确地推断 CT 体积, 为投影采集受限的场景提供应用的可能性。

(2) 为避免级联的三维卷积对显存和计算速度产生严重制约, 网络采用二维卷积替代三维卷积, 将通道维度编码为深度维度, 利用特征通道推断 CT 体积深度。这一做法可以在保证重建质量的同时减少计算量。

(3) 引入梯度图像和梯度损失提高网络对先验信息的利用, 加快模型的收敛速度, 增强网络对边缘的恢复能力。

## 1 网络架构

通常来说, 一张投影图像只包括该投影方向上的对象信息, 通过传统 CT 重建方法无法重建出高

质量的结果。深度学习方法通过不断优化模型参数来拟合投影到体积的映射函数。该方法使用由投影图像和对应的全视角 CT 重建体积组成的数据对进行训练, 在训练过程中它可以不断地获取先验信息。

本文构建一个基于正交双视角投影的快速三维重建网络。网络基于编解码架构, 采用二维卷积替代三维卷积, 利用特征通道推断 CT 体积深度, 提高 3D CT 重建速度。同时引入梯度图像和梯度损失, 加快模型的收敛速度, 增强网络对边缘的恢复能力。

首先计算正交双视角投影图像的梯度, 随后将原图像、梯度图像以及二者之和进行拼接。然后进行通道数扩展操作, 完成后进行维度对齐操作, 接着再输入到编解码网络中。最后通过特征重构恢复出目标体积数据。所提出的网络模型可分为 4 个模

块: 维度扩展模块、编码器模块、解码器模块、特征重构模块, 对应的数学模型分别为  $F_{de}$ 、 $F_{encoder}$ 、 $F_{decoder}$ 、 $F_{fr}$ 。网络模型拟合的 2D 投影图像到 3D CT 体积的映射函数  $F$  可以描述为式 1 所示,

$$F = F_{fr}(F_{de} \otimes F_{encoder} \otimes F_{decoder}), \quad (1)$$

其中  $\otimes$  表示网络模型级联。

通过对投影图像进行预处理得到一个包含梯度信息和原始先验信息的多通道数据。接着再进行通道扩展和对齐操作, 得到匹配目标 CT 体积深度的中间体积数据。然后输入到编码器中得到一个低维度高级特征<sup>[14]</sup>, 再通过解码器逐步重构高维特征。最后借助特征重构模块输出目标 CT 体积, 实现 3D CT 重建。

网络整体架构图如图 1 所示, 该模型各模块的设计如下。

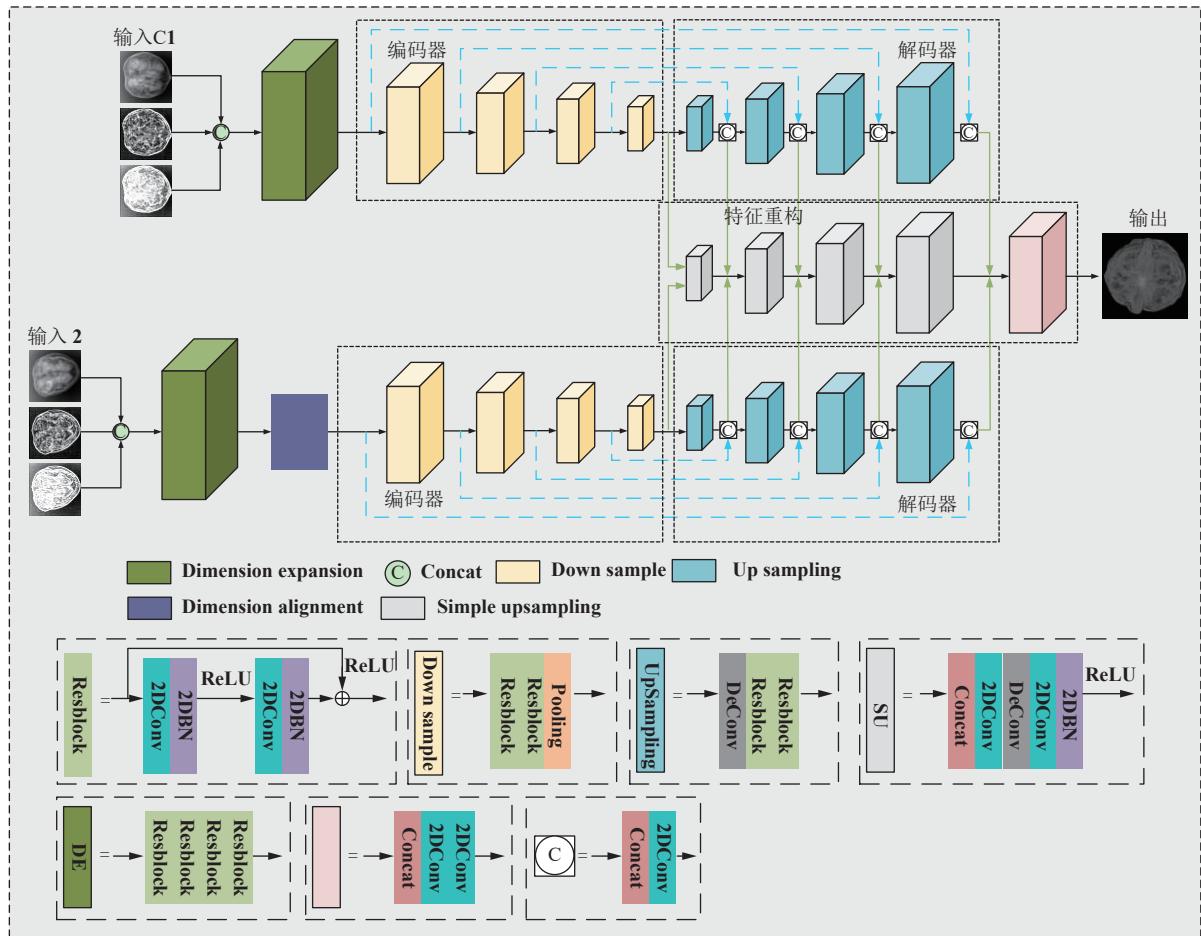


图 1 网络整体架构图

Fig.1 Overall network architecture

## 1.1 维度扩展模块

为了充分利用先验信息和增强模型对边缘的

恢复能力, 本文使用投影图像、梯度图像和二者之和作为输入。首先计算投影图像  $\{I_1, I_2\} \in R^{H \times W \times 1}$  的 Scharr 梯度, 得到  $\{I_3, I_4\} \in R^{H \times W \times 1}$ 。Scharr 梯度

计算公式如下：

$$G_x = \begin{bmatrix} -3 & 0 & 3 \\ -10 & 0 & 10 \\ -3 & 0 & 3 \end{bmatrix} \otimes A, \quad (2)$$

$$G_y = \begin{bmatrix} -3 & -10 & -3 \\ 0 & 0 & 0 \\ 3 & 10 & 3 \end{bmatrix} \otimes A$$

$$G(i, j) = \sqrt{(G_x(i, j))^2 + (G_y(i, j))^2}, \quad (3)$$

$$\theta(i, j) = \arctan\left(\frac{G_y(i, j)}{G_x(i, j)}\right)$$

其中， $A$  表示待处理的图像， $\otimes$  表示卷积， $G_x$  表示水平方向的梯度， $G_y$  表示垂直方向的梯度， $G$  表示梯度幅值， $\theta$  表示梯度方向。Scharf 梯度能够更精确地近似图像的真实梯度，而且在计算梯度时考虑了更多的邻域信息，对噪声具有一定的鲁棒性。

然后求投影图像和梯度图像的和，得到  $\{I_1 + I_3, I_2 + I_4\} \in R^{H \times W \times 1}$ 。最后将它们在通道维度上进行拼接，生成 3 通道初始数据  $\{I_5, I_6\} \in R^{H \times W \times 3}$ 。接着对初始数据进行通道数扩展操作，把通道维度编码为深度维度，利用特征通道推断 CT 体积深度。通道数扩展由 4 个级联的 ResBlock 块组成。随着 ResBlock 块的逐步执行，特征图的通道数呈阶梯式增长，依次为 3→16→32→64→128。在此过程中，网络持续探索深度信息，并将 3D 信息逐步嵌入特征图的不同通道内。最后再通过对齐操作，实现维度的统一。对齐操作示意图如图 2 所示。

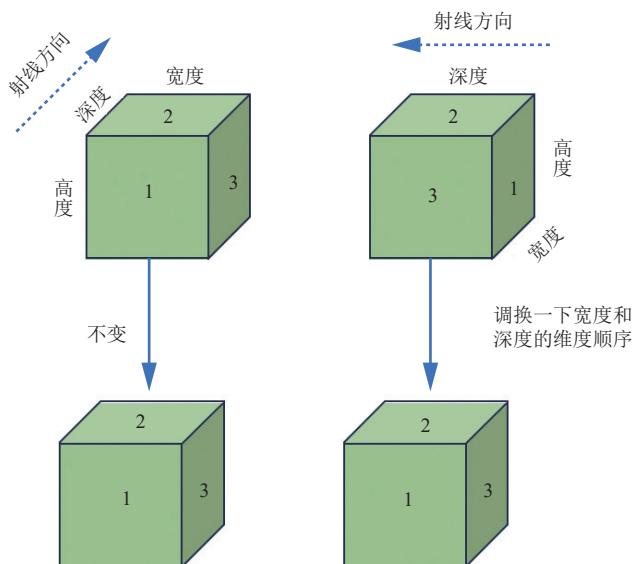


图 2 对齐操作示意图

Fig.2 Schematic of the alignment operation

## 1.2 编码模块

编码器将经过通道数扩展的初始 3D 体积数据作为输入，逐步对高维特征图进行压缩编码。随着下采样的进行，特征图的尺寸不断被压缩，但特征通道数保持不变，一直匹配目标 CT 体积数据的深度。在此过程中，感受野会逐渐扩大，可以感知到更多的低频信息<sup>[15]</sup>。在编码过程中，通过跳跃连接将不同级别特征信息直接传递给解码器，以共享特征信息加强信息利用。

编码器由 4 个级联的下采样块组成。其中，每个下采样块由“2D ResBlock layer→2D ResBlock layer→pooling layer”组成。通过逐步的下采样操作，特征图尺寸逐步为 128→64→32→16→8。

## 1.3 解码模块

解码器将经过编码的低维高级特征作为输入，逐步重构高维特征并恢复图像细节<sup>[16]</sup>。解码器由 4 个拼接融合操作和 4 个上采样模块组成，每个上采样块由一组“2D Deconvolution layer→2D ResBlock layer→2D ResBlock layer”组成。通过逐步的上采样操作，特征图尺寸依次为 8→16→32→64→128，但特征图通道数保持不变。

随着上采样的进行，模型将解码器自身的信息和来自编码器对应层级的特征信息一步一步融合，充分利用多尺度的信息，逐渐恢复目标图像的结构和细节。

## 1.4 特征重构模块

将两个解码器的结果与特征重构模块自身的结果在通道维度上进行拼接，随后使其通过二维卷积操作，以此实现特征信息的有效融合<sup>[17]</sup>。特征重构模块由 4 个简单上采样块组成。每个简单上采样块由一组“Concat→2D Conv layer→2D Deconvolution layer→2D Conv layer→2D Batch Normalization layer→ReLU layer”组成。

通过逐步的简单上采样操作，特征图尺寸依次为 8→16→32→64→128，但特征图通道数仍然保持不变。最后再通过 1 个拼接操作和 2 个二维卷积输出目标 CT 体积。

## 2 训练和推理细节

本文提出的网络模型采用正交投影图像、对应的梯度图像和二者的和作为输入。首先通过维度扩展得到匹配目标 CT 体积数据深度的初始体积

数据, 然后经过对齐操作实现维度统一, 接着再输入到编解码网络中, 最后通过特征重构模块输出预测 CT 体积。为了提升重建速度并降低显存需

求, 本文网络使用特征通道推断 CT 体积深度。整个网络以端到端的方式进行优化, 模型各层参数结构如表 1 所示。

表 1 模型各层参数结构  
Table 1 Parameter structure of each layer of the model

层	参数	输出尺寸 ( $H \times W \times C$ 格式)
维度扩展 $\times 2$	2D ResBlock $\times 4$	$128 \times 128 \times 128$
	Downsampling	$64 \times 64 \times 128$
编码网络 $\times 2$	Downsampling	$32 \times 32 \times 128$
	Downsampling	$16 \times 16 \times 128$
解码网络 $\times 2$	Downsampling	$8 \times 8 \times 128$
	Upsampling + Concat + 2D Conv	$16 \times 16 \times 128$
特征重构模块	Upsampling + Concat + 2D Conv	$32 \times 32 \times 128$
	Upsampling + Concat + 2D Conv	$64 \times 64 \times 128$
特征重构模块	Upsampling + Concat + 2D Conv	$128 \times 128 \times 128$
	Simple Upsampling	$16 \times 16 \times 128$
特征重构模块	Simple Upsampling	$32 \times 32 \times 128$
	Simple Upsampling	$64 \times 64 \times 128$
特征重构模块	Simple Upsampling	$128 \times 128 \times 128$
	Concat + 2D Conv + 2D Conv	$128 \times 128 \times 128$

网络采用 adam 优化器进行优化, 初始学习率设置为 0.0001, 并设置动量参数  $\beta_1$  为 0.9,  $\beta_2$  为 0.99。随着 epoch 数量的增加, 学习率采用线性衰减策略, 降低到  $10^{-8}$ 。本文实验设置批次处理大小为 12, 训练周期总数为 150。通过 Tensorflow2.4 平台实现了该网络, 并在配备了 NVIDIA Tesla V100 图形显卡的计算设备上进行训练、验证和测试。

### 3 实验

#### 3.1 数据集

为了训练本文提出的网络, 构建了一个包含有 4 个核桃的数据集, 该数据集由 2D 投影图像和 3D 体积数据组成。对于每个核桃, 使用微焦点 CT 系统 YXLON FF 20 (图 3) 获得全视图投影



图 3 FF 20 微焦点 CT 系统

Fig.3 FF 20 microfocus CT system

(1200 张) 和真值 CT 体积图像 (使用周向投影数据通过 FDK 算法重建得到的)。将两张正交 2D 投影图像和对应的 3D CT 体积命名一组数据, 总计  $4 \times 1200/2 = 2400$  组数据。

表 2 汇总所用的投影数据采集参数。按照 8:1:1 的比例划分数据集, 分别用于训练, 验证和测试。投影数据的维度大小为  $128 \times 128$ , 体积数据维度大小为  $128 \times 128 \times 128$ 。为了更好的训练和加速拟合, 对投影数据和体积数据进行了归一化处理。

表 2 FF 20 微焦点 CT 系统的数据采集参数  
Table 2 Data acquisition parameters of the FF 20 microfocus CT system

参数	数值
X 射线源到探测器的距离	780.577 mm
X 射线源到旋转中心的距离	155.22 mm
管电压	120 kV
管电流	40 $\mu$ A
X 射线源焦点尺寸	1 $\mu$ m
探元尺寸	0.127 mm
探测器分辨率	$1122 \times 1122$

#### 3.2 损失函数

为有效提升重建质量与精度, 增强模型鲁棒性, 本文构建了一个多维度约束的损失函数。该函数由重建损失、结构相似性损失和梯度损失 3 部分构成, 具体内容如下。

(1) 重建损失。使用均方误差 (mean squared

error, MSE) 作为重建损失函数。该损失是一种体素损失, 用于约束体素的结构一致性<sup>[18]</sup>, 确保模型在空间上重建出尽可能准确的 3D 模型。重建损失定义如下,

$$L_{\text{RE}}(Y_{\text{pred}}, Y_{\text{truth}}) = \|Y_{\text{pred}} - Y_{\text{truth}}\|_2^2, \quad (4)$$

其中,  $Y_{\text{pred}}$  表示网络模型预测的体积数据,  $Y_{\text{truth}}$  表示真实的体积数据。

(2) 结构相似性损失。结构相似性 (structural similarity, SSIM) 是衡量两幅图像相似度的指标, 综合比较亮度、对比度和结构相似度, 关注于图像的视觉质量和结构一致性<sup>[19]</sup>。因此, 引入基于 SSIM 的结构相似性损失, 损失函数定义为,

$$L_{\text{SSIM}}(Y_{\text{pred}}, Y_{\text{truth}}) = 1 - \text{SSIM}(Y_{\text{pred}}, Y_{\text{truth}}), \quad (5)$$

其中,  $Y_{\text{pred}}$  表示网络模型预测的体积数据,  $Y_{\text{truth}}$  表示真实的体积数据。

(3) 梯度损失。为了更好地恢复图像的结构信息和边缘细节, 本文引入了梯度损失。梯度损失关注图像的边缘和纹理信息, 可以在预测过程中保持图像的整体结构, 避免出现模糊现象。定义如下,

$$\text{MSE}_x = \frac{1}{DHW} \sum_{d=1}^D \sum_{h=1}^H \sum_{w=1}^W (\nabla_x Y_{\text{pred}} - \nabla_x Y_{\text{truth}})^2, \quad (6)$$

$$\text{MSE}_y = \frac{1}{DHW} \sum_{d=1}^D \sum_{h=1}^H \sum_{w=1}^W (\nabla_y Y_{\text{pred}} - \nabla_y Y_{\text{truth}})^2, \quad (7)$$

$$L_{\text{GL}}(Y_{\text{pred}}, Y_{\text{truth}}) = \frac{\text{MSE}_x + \text{MSE}_y}{2}, \quad (8)$$

其中,  $Y_{\text{pred}}$  表示网络模型预测的体积数据,  $Y_{\text{truth}}$  表示真实的体积数据,  $\text{MSE}_x$  为  $x$  方向梯度的均方误差,  $\text{MSE}_y$  为  $y$  方向梯度的均方误差。

综上, 总的优化目标定义如下,

$$L_{\text{total}} = \lambda_1 L_{\text{RE}} + \lambda_2 L_{\text{SSIM}} + \lambda_3 L_{\text{GL}}, \quad (9)$$

其中,  $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$  控制不同损失项的相对重要性。在本文的重建任务中优先考虑体素一致性, 故本文实验设置  $\lambda_1 = 1$ ,  $\lambda_2 = 0.1$ ,  $\lambda_3 = 0.1$ 。

### 3.3 对比方法

为了验证本文模型的有效性, 选取了 PatRecon<sup>[20]</sup> 和 X2CT-GAN 模型展开对比分析。

PatRecon 通过在通道维度上拼接正交双视角投影图像, 然后经过表示网络、转换模块和生成网络来实现正交双视角 CT 重建。表示网络用 2D 卷积残差块从 2D 投影中提取语义特征; 转换模块通过

卷积和反卷积操作跨维度转换特征; 生成网络基于 3D 反卷积块生成 3D CT 体积。X2CT-GAN 则借助生成对抗网络, 运用正交双视角投影图像生成 3D 医学解剖体积。并且该模型采用了一种创新的融合方法, 能够有效整合双视角投影携带的信息。

## 4 结果

### 4.1 视觉比较

为了公平起见, 本文提出的模型和对比模型均采用  $128 \times 128$  的投影图像重建分辨率为 128 的 CT 体积。PatRecon 和 X2CT-GAN 的架构与对应论文中的基本一致, 只改变了模型的输入和输出数据的维度, 以匹配本文的数据集。核桃的真实数据(使用周向投影数据通过 FDK 算法重建得到的)、测试结果和二者差异的切片图如图 4 所示。为了增强差异图的呈现效果, 本文将差异图的像素值放大 3.5 倍。

可以看出本文模型和对比模型都重建出令人满意的轮廓, 但从效果增强后的差异图可以看出 PatRecon 重建的结果与真值的差异最大, X2CT-GAN 次之。并且 PatRecon 和 X2CT-GAN 模型重建结果的图像纹理效果不如本文模型。同时在一些细小裂缝处(图 4 的红色方框), 本文模型重建的更清晰、更准确。

实验结果表明本文所提出的重建模型表现更为出色, 能够高效且精准地重建 3D CT 体积图像。

### 4.2 定量比较

本文选取均方根误差 (root mean squared error, RMSE)、峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性指数 (SSIM) 作为评估重建质量的指标。此外, 对于相同的测试集, 给出了测试阶段不同模型的推理时间。

所有实验在配备 NVIDIA Tesla V100 GPU (32G) 显卡的 Ubuntu 16.04 系统上进行, 定量结果如表 3 所示。可以看出本文模型在这 4 个指标上均优于 PatRecon 和 X2CT-GAN。实验结果显示本文模型从双视角 2D 投影中快速准确推断出 3D CT 体积的有效能力。

### 4.3 复杂度比较

本文还比较了这 3 种模型的参数量和浮点运算数(表 4)。本文模型避免了级联的三维卷积, 使用特征通道推断 CT 体积深度, 在模型复杂度和计

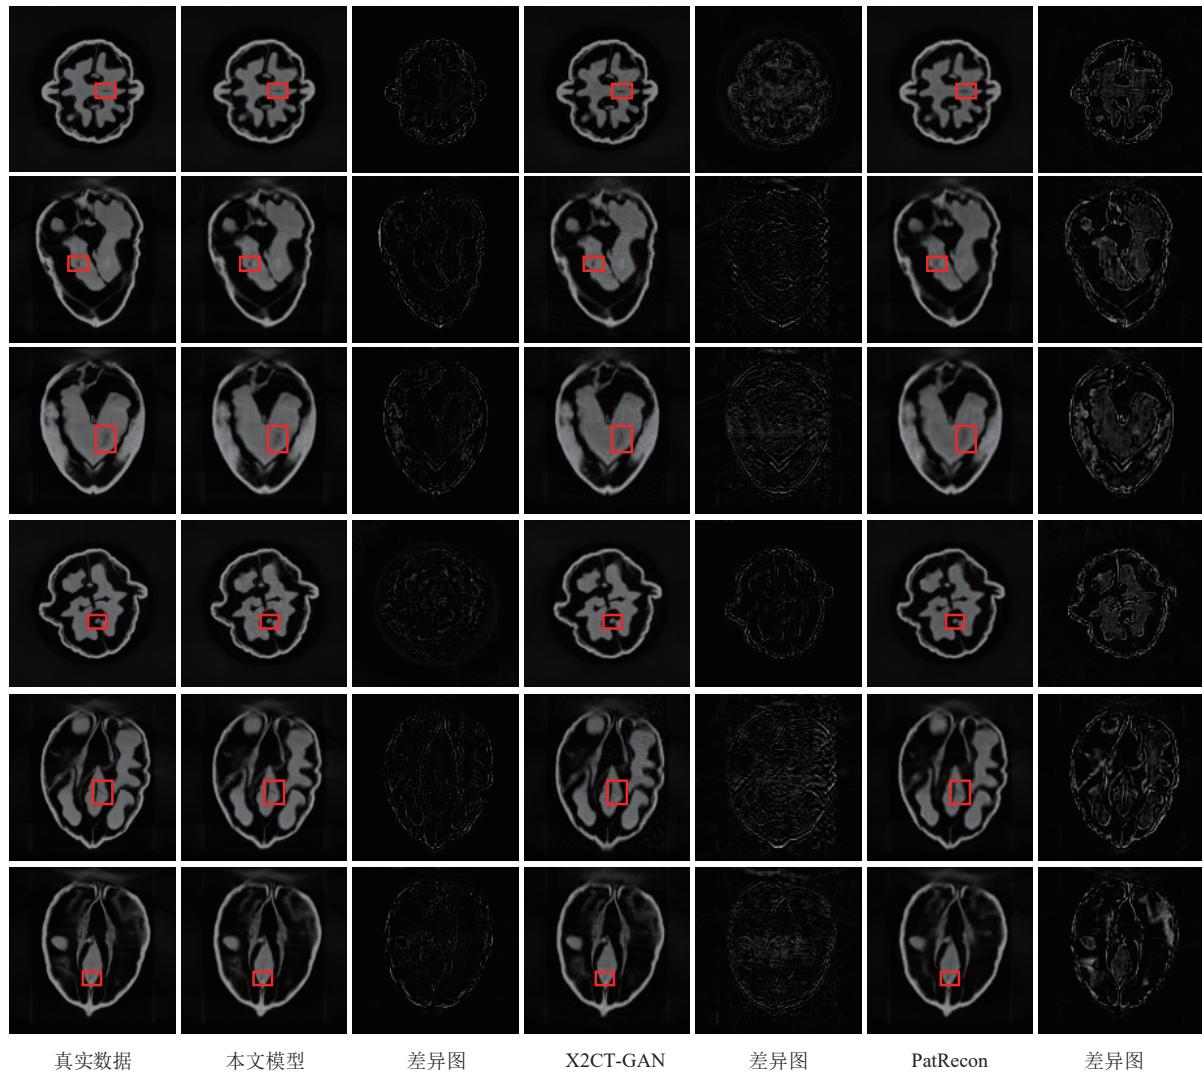


图 4 测试结果切片图

Fig.4 Slice diagram of the test results

表 3 定量比较结果  
Table 3 Quantitative comparison results

模型	RMSE	SSIM	PSNR	Testing time/s
本文方法	0.011	0.988	38.942	0.19
X2CT-GAN	0.013	0.975	37.583	0.63
PatRecon	0.015	0.961	36.763	2.75

算复杂度方面都呈现出一定的优势。

在模型复杂度方面, 本文模型展现出显著的轻量化特性, 其参数量只有 16.9M, 远远低于 PatRecon。在计算复杂度方面, 本文模型的浮点运算量为  $179.44 \times 10^9$ , 低于 PatRecon 和 X2CT-GAN 模型。结果表明, 本文模型具有很小的模型参数量和很低的计算资源消耗, 为快速准确三维重建提供了更优的方案。

#### 4.4 鲁棒性验证

为了验证本文模型的鲁棒性, 还构建了一个包

表 4 模型参数量和 FLOPs 比较结果  
Table 4 Comparison results of the number of model parameters and FLOPs

模型	Param./( $\times 10^7$ )	FLOPs/( $\times 10^9$ )
本文方法	1.69	179.44
X2CT-GAN	7.28	392.88
PatRecon	58.86	1304.12

含有 6 种引信装配情况的数据集。该数据集一共有  $6 \times 1080/2 = 3240$  组数据。按照 8:1:1 的比例划分数据集, 分别用于训练, 验证和测试。其中一种引信装配情况的测试结果切片图如图 5 所示。

第 1 行是真实数据 (使用周向投影数据通过 FDK 算法重建得到的) 3 个维度方向的切片图, 第 2 行是测试结果的切片图。可以看出本文模型重建出了正确的撞针方向, 同时其整体几何构型与真实数据也高度一致。结果表明, 本文模型在引信数据上取得了良好的效果, 验证了该模型的鲁棒性。

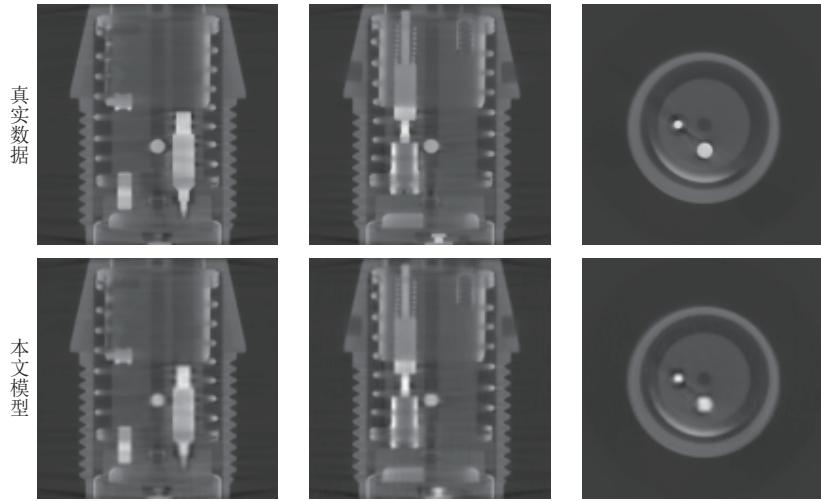


图 5 引信数据测试结果切片图  
Fig.5 Slice diagram of the test results for fuze data

表 5 模型对比结果  
Table 5 Comparison results of models

模型	SSIM	PSNR	Param. / ( $\times 10^7$ )	FLOPs / ( $\times 10^9$ )	Testing time/s
本文模型 (二维卷积)	0.988	38.942	1.69	179.44	0.19
本文模型 (三维卷积)	0.985	38.175	0.89	488.15	0.87

#### 4.5 模型结构选择

为了进一步展现利用二维卷积替代三维卷积的优势, 本文还构建了一个特殊的双视角重建网络。该网络的架构和上面的图 1 基本一致, 只是在编解码和特征重构模块中用三维卷积替代了二维卷积。之后, 在相同的软硬件配置下, 使用同样的数据集和损失函数, 进行训练、验证和测试。表 5 展示了对比结果。

可以看出两个模型的重建质量基本一致, 但使用二维卷积替代三维卷积可以在测试时间上带来很大的提升。由于二维卷积模型需要用通道数维度推测深度维度, 在特征编解码和特征重构阶段必须保持 128 个通道数不变, 而三维卷积模型无此约束, 因此二维卷积模型的参数量要高于三维卷积模型。结果表明, 为了进行快速高质量 CT 重建, 利用二维卷积替代三维卷积这一思路很有优势。

### 5 结论与讨论

综上所述, 本研究提出的正交双视角三维重构网络有效解决了极端受限扫描条件下 CT 重建的不稳定性难题, 在重建速度、图像质量、模型参数量和计算复杂度方面都展现出一定优势。

使用二维卷积替代三维卷积, 利用特征通道维度推断 CT 体积的深度维度, 可以减小模型的推理

时间。引入梯度信息、梯度损失, 可以加快模型的收敛速度, 增强网络对边缘的恢复能力。将该算法与 PatRecon 和 X2CT-GAN 算法进行比较, 实验结果表明该算法具有更好的重建效果、较低的模型参数量和较快的重建速度。

今后仍需要在该研究的基础上, 继续深入开展后续研究, 引入神经辐射场的思想, 着重提升模型的泛化性。将物体的密度场建模为隐函数, 构建坐标到 CT 密度场的隐式表征, 实现 2D 投影图像中像素和 3D CT 体积中体素的对应。并且加入符合 CT 扫描物理原理的损失函数, 让网络学习 CT 成像的物理过程, 增强模型的泛化性和可解释性。

### 参考文献

- [1] 刘勇, 曾理. 工业 CT 图像的管道圆柱度误差测量[J]. *计算机工程与应用*, 2011, 47(13): 199-200, 233. DOI:10.3778/j.issn.1002-8331.2011.13.056.
- [2] LIU Y, ZENG L. Cylindricity error evaluation of pipe in industrial CT images[J]. *Computer Engineering and Applications*, 2011, 47(13): 199-200, 233. DOI:10.3778/j.issn.1002-8331.2011.13.056. (in Chinese).
- [3] 汤戈, 赵欣雨, 王宇翔, 等. 工业 CT 技术在地球科学中的应用[J]. *CT 理论与应用研究 (中英文)*, 2024, 33(1): 119-134. DOI:10.15953/j.ctta.2023.091.
- [4] TANG G, ZHAO X Y, WANG Y X, et al. Applications of industrial computed tomography technology in the

- geosciences[J]. *CT Theory and Applications*, 2024, 33(1): 119-134. DOI:10.15953/j.ctta.2023.091. (in Chinese).
- [3] 邸江磊, 林俊成, 钟丽云, 等. 基于深度学习的稀疏或有限角度 CT 重建方法研究综述[J]. 激光与光电子学进展, 2023, 60(8): 32-69. DOI:10.3788/LOP230488.
- DI J L, LIN J C, ZHONG L Y, et al. Review of sparse-view or limited-angle CT reconstruction based on deep learning[J]. *Laser & Optoelectronics Progress*, 2023, 60(8): 32-69. DOI:10.3788/LOP230488. (in Chinese).
- [4] 樊雪林, 文昱齐, 乔志伟. 基于 Transformer 增强型 U-net 的 CT 图像稀疏重建与伪影抑制[J]. *CT 理论与应用研究 (中英文)*, 2024, 33(1): 1-12. DOI:10.15953/j.ctta.2023.183.
- FAN X L, WEN Y Q, QIAO Z W. Sparse reconstruction of computed tomography images with transformer enhanced U-net[J]. *CT Theory and Applications*, 2024, 33(1): 1-12. DOI:10.15953/j.ctta.2023.183. (in Chinese).
- [5] LI X, WANG S, CHEN P, et al. 3-D inspection method for industrial product assembly based on single X-ray projections[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-14.
- TAN Z, LI J, TAO H, et al. XctNet: Reconstruction network of volumetric images from a single X-ray image[J]. *Computerized Medical Imaging and Graphics*, 2022, 98: 102067. DOI:10.1016/j.compmedimag.2022.102067.
- [7] LIU X, YU J, SUN Y, et al. Tiny defect oriented single-view CT reconstruction based on a hybrid framework[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024.
- SUN X, LI X, CHEN P. An ultra-sparse view CT imaging method based on X-ray2CTNet[J]. *IEEE Transactions on Computational Imaging*, 2022, 8: 733-742. DOI:10.1109/TCI.2022.3201390.
- [9] YING X, GUO H, MA K, et al. X2CT-GAN: Reconstructing CT from biplanar X-rays with generative adversarial networks[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019: 10619-10628.
- [10] HUANG C, LI K, FANG J, et al. 3DSP-GAN: A 3D-to-3D network for CT reconstruction from biplane X-rays[C]//2024 IEEE 7th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). IEEE, 2024, 7: 931-935.
- [11] SHI Z, GENG K, ZHAO X, et al. XRayWizard: Reconstructing 3-D lung surfaces from a single 2-D chest X-ray image via Vision Transformer[J]. *Medical Physics*, 2024, 51(4): 2806-2816. DOI:10.1002/mp.16781.
- [12] WANG Y, SUN Z L, ZENG Z, et al. TRCT-GAN: CT reconstruction from biplane X-rays using transformer and generative adversarial networks[J]. *Digital Signal Processing*, 2023, 140: 104123. DOI:10.1016/j.dsp.2023.104123.
- [13] 孙雪琴. 基于超稀疏视角 CT 成像的固体火箭发动机燃面退移测试方法研究[D]. 太原: 中北大学, 2024. DOI:10.27470/d.cnki.ghbdc.2024.000018.
- SUN X Q. Testing method of solid rocket motor burning surfaceregression based on ultra-sparse view CT imaging[D]. Taiyuan: North University of China, 2024. DOI:10.27470/d.cnki.ghbdc.2024.000018. (in Chinese).
- [14] 杨甜添. 基于多尺度特征和自注意力机制的 MRI 心脏图像分割算法研究[D]. 武汉: 武汉纺织大学, 2024. DOI:10.27698/d.cnki.gwhxj.2024.000395.
- YANG T T. Research on MRI Heart Image segmentationalgorithm based on multi-scale features and self-attention mechanism[D]. Wuhan: Wuhan Textile University, 2024. DOI:10.27698/d.cnki.gwhxj.2024.000395. (in Chinese).
- [15] 邱怡, 包乾宗, 马铭, 等. 基于 U-Net 网络的二维小波域地震数据随机噪声衰减[J]. *石油物探*, 2023, 62(5): 878-890. DOI:10.12431/issn.1000-1441.2023.62.05.007.
- QIU Y, BAO Q Z, MA M, et al. Seismic data random noise attenuation using U-Net network in the 2D discrete wavelet domain[J]. *Geophysical Prospecting for Petroleum*, 2023, 62(5): 878-890. DOI:10.12431/issn.1000-1441.2023.62.05.007. (in Chinese).
- [16] 孙卓群, 赵加祥. 基于多尺度注意力小波网络的可适应病变规模超声乳腺图像分割[J]. *微电子学与计算机*, 2023, 40(12): 45-52. DOI:10.19304/J.ISSN1000-7180.2022.0901.
- SUN Z Q, ZHAO J X. Adaptive lesion scale ultrasound breast image segmentation based on multi-scale attention wavelet network[J]. *Microelectronics & Computer*, 2023, 40(12): 45-52. DOI:10.19304/J.ISSN1000-7180.2022.0901. (in Chinese).
- [17] 苏申申, 周卫, 周淋芋, 等. 基于 MobileViT 轻量化网络的蘑菇图像分类算法改进[J]. *现代计算机*, 2024, 30(21): 69-73.
- [18] 王苏恺. 基于深度学习的稀疏角 CT 重建算法研究[D]. 太原: 中北大学, 2022. DOI:10.27470/d.cnki.ghbdc.2022.001319.
- WANG S K. Research on sparse-view CT reconstruction-algorithm based on deep learning[D]. Taiyuan: North University of China, 2022. DOI:10.27470/d.cnki.ghbdc.2022.001319. (in Chinese).
- [19] 向锐. 基于边缘和结构一致性的红外-可见光图像转换算法研究[D]. 武汉: 华中科技大学, 2023. DOI:10.27157/d.cnki.ghzku.2023.003074.
- XIANG R. Research on infrared-visible image conversion algorithm based on edge and structure consistency[D]. Wuhan: Huazhong University of Science and Technology, 2023. DOI:10.27157/d.cnki.ghzku.2023.003074. (in Chinese).
- [20] SHEN L, ZHAO W, XING L. Patient-specific reconstruction of volumetric computed tomography images from a single projection view via deep learning[J]. *Nature Biomedical Engineering*, 2019, 3(11): 880-888. DOI:10.1038/s41551-019-0466-4.